

Classificação e Análise de Modelos de Predição de Trajetórias e de Destinos - Um Mapeamento Sistemático da Literatura

João Batista Firmino Júnior¹, Janderson Ferreira Dutra¹, Francisco Dantas Nobre Neto¹

¹Programa de Pós-Graduação em Tecnologia da Informação – Instituto Federal da Paraíba (IFPB)

Caixa Postal 58015-435 – João Pessoa – PB – Brasil

batista.firmino@academico.ifpb.edu.br, janderson.dutra@ifpb.edu.br,
dantas.nobre@ifpb.edu.br

Abstract. *Predicting routes and destinations has considerable relevance in the context of urban mobility, being useful to suggest detours, avoid traffic jams and optimize people's movements. Therefore, this research performs a classification and analysis of trajectory and destination prediction models in articles published from 2017 to 2022. These models were mapped considering: authors; if there was more than one geographic setting; type of prediction; use of semantic and contextual data; and the description of the algorithms. The result consists of discussions of representative works, based on the classification, with the grouping of techniques.*

Resumo. *Realizar predição de trajetórias e destinos tem relevância considerável no contexto de mobilidade urbana, sendo útil para sugerir desvios, evitar congestionamentos e otimizar deslocamentos de pessoas. Por isso, esta pesquisa realiza uma classificação e análise de modelos de predição de trajetórias e de destinos em artigos publicados no período de 2017 a 2022. Esses modelos foram mapeados considerando: autores; se houve mais de um cenário geográfico; tipo de predição; uso de dados semânticos e contextuais; e a descrição dos algoritmos. O resultado consiste nas discussões dos trabalhos representativos, a partir da classificação, com o agrupamento de técnicas.*

1. Introdução

Nos últimos anos, muitos trabalhos sobre predição de trajetórias e destinos foram feitos com o objetivo de explorar algum método ou algoritmo específico que melhore a precisão das predições. Pesquisas centradas em modelos preditivos alcançaram resultados variados, servindo como base para novas investigações e identificação de desafios inerentes a esta temática.

Diante da variabilidade desses modelos, das formas de abordagem e seus resultados e desafios, observou-se a necessidade de, para o período de 2017 a 2022, ser realizado um Mapeamento Sistemático da Literatura (MSL). É nesse espaço de evolução que se busca um mapeamento capaz de descrever e analisar certas técnicas, métodos, ainda que somente uma parte dos algoritmos desenvolvidos, para trazer subsídios a outros pesquisadores em novas pesquisas.

Com a finalidade de se ter um quadro atualizado das pesquisas mais recentes em determinada área do conhecimento, algumas ferramentas para levantamento e análise da literatura são essenciais. Dentre as ferramentas possíveis, este MSL buscou classificar e analisar trabalhos inerentes ao estado da arte na temática pesquisada.

Para tal, a análise foi feita parcialmente baseada no protocolo definido por Kitchenham e Charters (2007), que inclui o plano detalhado para a revisão, especificando o processo a ser seguido e as condições para aplicá-lo na seleção de estudos primários. Sendo o escopo de pesquisa presente neste MSL em predição de trajetórias e/ou de destinos, em que foram definidos critérios objetivos para a seleção de artigos da literatura, a principal contribuição deste estudo é a de evidenciar modelos que sejam um caminho para a resolução da seguinte Questão de Pesquisa: “Como foram construídos os modelos de predição de trajetória e/ou de destinos, de 2017 a 2022?”.

Além desta seção introdutória, este artigo está estruturado da seguinte forma: na Seção 2, há a Fundamentação Teórica; na Seção 3, é destacada a metodologia de condução do MSL; na Seção 4, são explicados os resultados obtidos; e, por fim, a Seção 5 apresenta a conclusão.

2. Fundamentação Teórica

Esta seção introduz os principais conceitos associados às linhas de pesquisa com predição de trajetórias.

Definição 1 - Predição de Trajetórias. Esse tipo de predição propõe-se a encontrar as possíveis trajetórias que poderão ser seguidas a partir de dados históricos. Para Li et al. (2021), considerando um objeto em movimento, trajetória é uma sequência finita, uma ordenação sequencial de pontos espaço-temporais, que é amostrado de um rastreamento mediante algum dispositivo de localização. Tal predição, pode envolver dados associados ao propósito de cada trajeto como, por exemplo, dados semânticos (Sadri et al., 2018).

Definição 2 - Dados semânticos. São dados relativos à função de um lugar, como um destino. É de se observar que, um mesmo local pode representar semânticas diferentes para usuários com perfis diferentes. Um exemplo consiste na captação de pontos de movimento e dos pontos de parada para enriquecimento semântico, sendo possível inferir a motivação para esses diferentes estados em que se encontram os objetos em movimento (Santana e Campos, 2017).

Definição 3 - Dados geográficos. Considerando trajetórias, este conceito se refere às representações computacionais em que os atributos são computacionalmente tratados e armazenados com as respectivas geometrias, mediante um Sistema de Informações Geográficas (SIG) (Druck et al., 2005). Isso significa a dependência da presença de coordenadas geográficas.

Definição 4 - Dados temporais. Este conceito consiste em dados do tipo *datetime*, que se revela mediante o formato de data acrescido de horas, minutos e segundos. Podem possuir uma zona específica com uma contagem temporal própria ou ser *Universal Time Coordinate* (UTC) ou *Global Time Greenwich Mean Time* (GMT), que são padrões internacionais, que valem para todo o planeta. O primeiro foi inicialmente concebido no início dos anos 1960, para melhorar a disseminação de um sistema anterior, o UT1. Nele, é utilizado *Global Navigation Satellite Systems* (GNSS), de acordo com Arias e Guinot

(2004). O segundo significa o tempo solar e, de acordo com o Observatório Real de Greenwich, é mais antigo que o UTC, mas não deve ser utilizado para propósitos mais precisos, conforme Weinrit (2017). Em síntese: são dados que trazem a ideia de continuidade do fenômeno sobre determinado espaço.

Definição 5 - Dados contextuais. Consiste em dados comuns a todos os usuários, e dizem respeito ao contexto ou local em que se situam os eventos, tais como, dados de clima, dados topográficos (em relação ao terreno), sinais de trânsito e dia da semana. Liu et al. (2019) consideram, por exemplo, o número de táxis solicitado, a demanda de viagens (o *Local Spatial Context*), se todos os distritos são residenciais (que os autores chamam de *Global Relational Context*) e dados meteorológicos (destacados como *Temporal Evolution Context*).

3. Metodologia

A pesquisa foi realizada no contexto de trabalhos recentes (de 2017 até 2022), tendo-se por referência a Questão de Pesquisa citada na seção de Introdução. O método adotado contemplou as três principais etapas propostas por Kitchenham e Charters (2007), resumidas na Figura 1.

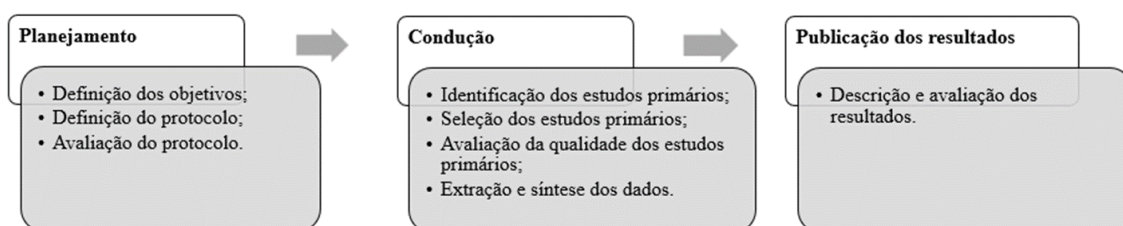


Figura 1. Etapas seguidas no MSL [adaptado de Kitchenham e Charters (2007)].

Foram consideradas, inicialmente, as seguintes bases de buscas: *Association for Computing Machinery (ACM) Digital Library*, *Institute of Electrical and Electronics (IEEE) Xplore*, *Tandfonline*, *GEOINFO*, *IJCAI-17* e o buscador da Sociedade Brasileira de Computação (SBC). Quanto aos artigos da SBC, a busca foi feita com base em termos como “rotas”, “predição de rotas”, “routes” e “route prediction”. Para as demais bases foi aplicada *string* de busca: (“trajectory prediction” OR “destination prediction” OR “route planning”) AND “roads”.

Na etapa de condução os estudos primários recuperados foram lidos e avaliados, inicialmente, pelos títulos, palavras-chaves, resumos, introduções e conclusões. Finalmente, foi realizada a leitura completa dos estudos, em busca de uma possível correlação de padrões entre esses trabalhos recentes.

Os critérios de inclusão para seleção dos artigos foram: (i) estar nos idiomas inglês ou português; (ii) ser um estudo completo (evitando-se artigos com soluções ainda em andamento); e (iii) ter sido publicado com até 5 anos em relação a 2022; (iv) uso de meios de transporte urbanos como, por exemplo, bicicletas, carros e ônibus, ou trajetos a pé.

Foram excluídos trabalhos: (i) com abordagem indireta ao tema deste artigo, tais como previsão de velocidades, focados mais em planejamento de rotas sem contemplar predição de trajetórias ou de destinos; (ii) completamente fora do tema, como os de redes e Internet, ou abordando certos objetos em movimento fora do contexto urbano ou rodoviário, como aviões e embarcações; (iii) referentes a veículos autônomos ou cuja técnica ou objeto de investigação contemplasse a temática de visão computacional.

Os critérios de qualidade considerados foram: presença de *datasets* reais para validação das soluções propostas nos trabalhos; acesso aos scripts e *datasets* com os dados já padronizados. Os dados foram extraídos, sintetizados e organizados em uma planilha eletrônica¹. Por fim, os resultados do MSL foram descritos e avaliados.

4. Resultados

A partir das leituras e análises realizadas, chegou-se a uma sumarização do que foi encontrado com a classificação e as análises.

A classificação, por autores, cenários geográficos, tipo de predição, dados semânticos e contexto, segue conforme no Quadro 1. Esta tabela possui seis colunas, em que: a primeira contém os autores dos trabalhos analisados; a segunda indica se houve mais de um cenário geográfico, com sim (S) ou não (N); a terceira contempla o tipo de predição realizado no trabalho, em que o valor “C” representa predição coletiva, e o valor “I” representa predição individual, e (I e C) para ambas; a quarta inclui se houve (S) ou não (N) a utilização de dados semânticos nos modelos preditivos; e a quinta coluna traz o contexto da predição realizada, em que o valor “U” representa que as predições foram feitas em ambiente urbano, e “O” representa “Outros” tipos de lugares. Uma última coluna descreve os algoritmos utilizados por artigo.

Quadro 1. Classificação dos modelos analisados.

Autores	Mais de 1 Cenário	Tipo de predição	Dados Semânticos	Contexto	Algoritmos
Wang et al., 2017	S	C	S	U	Algoritmos de treinamento e de predição
Imai et al., 2018	N	I	N	U	Algoritmos de Agrupamento
Vahedian et al., 2017	N	C	N	U	Algoritmos de Aprendizado e Agrupamento
Sadri et al., 2018	S	I	S	U	PreHeat e o “TrAf”
Chen et al., 2019	N	C	N	U	<i>Long-short Term Memory</i> (LSTM)
Ma e Xie, 2021	N	C	N	U	FCM (Fuzzy C-means) <i>Algorithm</i> e LSTM
Fu e Lee, 2020	S	I	N	U	<i>Recurrent Neural Networks</i> (RNN) e o <i>Gradient Descent</i>

¹ Disponível em: docs.google.com/spreadsheets/d/1z417YC284bzfDbWIW2jKiRjxMtz5H219XnheRqV5NZs/edit#gid=1797368344

Autores	Mais de 1 Cenário	Tipo de predição	Dados Semânticos	Contexto	Algoritmos
Barth et al., 2020	S	I e C	S	U	<i>Personalized Path Trajectory Segmentation (PPTS), e Optimal Path Trajectory Segmentation (OPTS)</i>
Liu et al., 2019	N	C	S	U	Algoritmos de redes neurais profundas
Tang et al., 2021	N	C	S	U	<i>Ridesharing Group Discovery e P-PPM Destination Prediction</i>
Liang e Zhao, 2022	S	I	N	U	<i>Generating Output Trajectory e LSTM</i>
Dai et al., 2019	N	I	N	O	LSTM
Rainbow et al., 2021	S	I	S	U	Algoritmos de redes neurais profundas
Besse et al., 2018	S	C	S	U	<i>Hierarchical Clustering (para Distribuições Gaussianas)</i>
Jiang et al., 2022	N	I	S	U	<i>Decision Assistant e Crowd-Sourced Rebalancing</i>
Fan e Yao, 2017	N	I	N	U	<i>Transfer map into fixed points e Road-Based Location Sign (RBLS)</i>
Ning, 2021	N	C	N	U	LSTM
Zhang et al., 2018	N	I	N	U	<i>Echo State Network (ESN), LSTM e Kalman Filter</i>
Wu et al., 2020	N	I	S	U	<i>Pedestrian Trajectory Prediction Algorithm</i>
Ebebel et al., 2020	S	I	N	O	LSTM
Lassoued, 2017	S	C	S	O	<i>Cluster Prediction como estados ocultos</i>
Qiao et al., 2018	S	C	S	O	PrefixTP
Bhuvaneswari et al., 2017	S	C	N	O	<i>SAHDID Prediction Algorithm</i>

Autores	Mais de 1 Cenário	Tipo de predição	Dados Semânticos	Contexto	Algoritmos
Selvaraj et al., 2021	S	I	N	U	LSTM
Choi et al., 2019	S	I	N	U	<i>Feed-Foward Neural Network (FFNN)</i>
Yuan e Li, 2019	N	I	N	O	DISON - baseado em similaridade de trajetórias, filtragem e refinamento
Tong et al., 2021	N	I	S	U	<i>Dijkstra Algorithm, Tabu-Based Expansion e Greedy Expansion Algorithm</i>
Ren et al., 2022	S	I	S	U	DBSCAN, Brooks-lyengar (BI) Algorithm e K-means
Santana e Campos, 2017	N	I	S	O	Algoritmo que agrupa pontos, ou pontos isolados
Araújo et al., 2019	S	C	S	U	<i>Temporal Markov Model with User Similarity (TEMMUS)</i>

Os principais resultados mostram que: (i) Apenas dois dos 30 trabalhos vieram com referência aos *scripts* (os artigos de Besse et al., 2018, e o de Barth et al., 2020); (ii) Metade dos trabalhos produziram modelos baseados em mais de um cenário geográfico; (iii) Dez trabalhos produziram modelos para prever trajetórias ou destinos para usuários coletivos (sendo o de Barth et al., 2020, tanto para usuários individuais como coletivos); (iv) Metade dos trabalhos utilizou dados semânticos; (v) Apenas sete trabalhos construíram seus modelos sem se basear no ambiente urbano.

Em comum, as técnicas mais abordadas foram as Redes Neurais, os Modelos de Markov e as de Agrupamento. Desses três casos, é possível detalhar uma de cada, como Imai et al. (2017), que utilizaram técnicas de agrupamento (o DBSCAN), e tal modelo se concentra no comportamento do usuário, em dados contextuais para a predição de destinos, e se sustenta em técnicas que envolvem rastreamento de trajetórias e *Next Place Prediction* (NPP). A performance foi avaliada com medidas de acurácia, além de percentil dos *top-k* destinos corretos; em seguida, compararam a *baseline* adotada com uma regressão logística multi-classe em combinação com *naive bayes*. O modelo proposto obteve uma acurácia entre 0.75 e 0.8. Uma limitação consiste no agrupamento para um número ilimitado de destinos, que ainda está em aberto. Os algoritmos utilizados foram o *SubSynE Algorithm* e o DBSCAN.

Quanto ao modelo de Ning (2021), baseou-se em Long Short Term Memory (LSTM) - que, inclusive, repete-se algumas vezes entre os algoritmos utilizados pelos 30

modelos -, fazendo a compressão dos dados de trajetória de 14 mil táxis de junho de 2019 numa área de 3640 quilômetros quadrados; após isso, a filtragem de ruídos. Fez-se também o uso de múltiplas fontes para a extração de dados, para diferentes perspectivas sobre o fenômeno, isso se deu com a extração de dados climáticos (contextuais), divididos em classes: ensolarado, chuva leve, chuva moderada, chuva pesada e chuva torrencial.

Além desses estudos, tem-se o de Araújo et al. (2019), que traz o “TEMMUS” (*Temporal Markov Model with User Similarity*), um modelo de previsão de trajetórias baseado em modelos de Markov por similaridade. A métrica de avaliação é a acurácia.

Além desses trabalhos, escolhidos como representativos das técnicas mais enfatizadas nos 30 modelos, muitos outros se baseiam em dados reais e técnicas cuja avaliação estatística dos resultados (as técnicas de avaliação) variaram, tal como o já citado Ning (2021), com as métricas *Mean Relative Percentage Error* (MRPE), *Mean Absolute Error* (MAE), *Mean Relative Error* (MRE), *Root Mean Squared Error* (RMSE) e o coeficiente de determinação R² e Imai et al. (2017).

Percebe-se que essa variação é de acordo com os propósitos de cada modelo. Ainda não foi possível encontrar um padrão de técnicas de avaliação estatística (quantitativa), ou mesmo qualitativa, dos resultados.

5. Conclusão

Por ser um campo relativamente recente, o de previsão de trajetórias e destinos, com dados semânticos ou não, observou-se a necessidade de métricas adaptadas - junto às novas técnicas, algoritmos, métodos ou frameworks. Além disso, percebeu-se essa ausência de especialistas da área de Transportes e nenhuma observação explícita sobre o campo dos Sistemas de Referência de Coordenadas, tão importante nos SIG.

Em geral, houve a predominância de dados reais para a validação e produção dos resultados; pouca frequência na disponibilização direta dos scripts ou mesmo pouca frequência no acesso aos dados originais, para a reprodutibilidade; pouco destaque a como trabalharam com Sistemas de Referência de Coordenadas e eventuais transformações entre sistemas; e predomínio de cenários urbanos.

Assim, algumas oportunidades de pesquisa se avizinham: a exploração de informações relevantes de trajetórias mediante SIG, e, a depender da maturação desses estudos, um diálogo produtivo com especialistas em Transportes - sobretudo, urbanos -, e a consolidação de novas métricas de validação com profissionais estatísticos.

Referências

- Araújo, F. R. De; Rosário, D. L.; Machado, K.; Cerqueira, E. C.; Villas, L. (2019). “TEMMUS: A Mobility Predictor based on Temporal Markov Model with User Similarity.”. In: Simpósio Brasileiro De Redes De Computadores E Sistemas Distribuídos (SBRC). Anais do XXXVII Simpósio Brasileiro de Redes de Computadores e Sistemas Distribuídos (SBRC 2019). Porto Alegre: Sociedade Brasileira de Computação. p. 594-607. ISSN 2177-9384. DOI: [10.5753/sbrc.2019.7389](https://doi.org/10.5753/sbrc.2019.7389).
- Arias, E. F.; Guinot, B. (2004). “Coordinated Universal Time UTC: historical background and perspectives”. SESSION II: MODELS FOR EARTH ROTATION: FROM POINCARÉ TO IAU 2000 43 Dehant V., de Viron O., Van Hoolst T.: Poincaré flow in the Earth’s core..... 45 Capitaine N., Wallace PT: Improvements in the precession-

- nutiation models..... 49 Hilton JL: Progress report of the International Astronomical Union Division I Work, p. 254.
- Barth, F.; Funke, S.; Jepsen, T. S.; Proissl (2020). “Scalable unsupervised multi-criteria trajectory segmentation and driving preference mining”. In: Proceedings Of The 9th Acm Sigspatial International Workshop On Analytics For Big Geospatial Data. Seattle Washington: ACM, 2020. p. 1-10. DOI: [10.1145/3423336.3429348](https://doi.org/10.1145/3423336.3429348).
- Besse, P. C.; Guillouet, B.; Loube, J.-M.; Royer, F. (2018) “Destination prediction by trajectory distribution-based model”. IEEE Transactions On Intelligent Transportation Systems: A Publication Of The IEEE Intelligent Transportation Systems Council. v. 19, n. 8, p. 2470–2481, 2018. DOI: [10.1109/TITS.2017.2749413](https://doi.org/10.1109/TITS.2017.2749413).
- Bhuvanewari, M.; Jyothirbindhu, V.; Paramasivan, B. (2017). “Statistical adaptive heuristic model supported driver intended destination and path prediction algorithm for vehicular ad hoc network” In: 2017 International Conference On Algorithms, Methodology, Models And Applications In Emerging Technologies (ICAMMAET). (Anais). IEEE, 2017. p. 1-6. DOI: [10.1109/ICAMMAET.2017.8186749](https://doi.org/10.1109/ICAMMAET.2017.8186749).
- Chen, Z.; Liu, H.; Wang, Y.; Duan, Z.; Chen, C. “E-dam: Encoder-decoder with attention mechanism for city-scale taxi trajectory prediction”. In: Proceedings Of The 2019 3rd International Conference On Computer Science And Artificial Intelligence. (Anais...). New York, NY, USA: ACM, 2019. DOI: [10.1145/3374587.3374610](https://doi.org/10.1145/3374587.3374610).
- Choi, S.; Kim, J.; Yu, H.; Yeo, H. (2019). “Real-time prediction of arterial vehicle trajectories: An application to predictive route guidance for an emergency vehicle.”. In: 2019 IEEE Intelligent Transportation Systems Conference (ITSC). (Anais...). IEEE, 2019. p. 4030-4036. DOI: [10.1109/ITSC.2019.8917122](https://doi.org/10.1109/ITSC.2019.8917122).
- Dai, S.; Li, L.; Li, Z. (2019). “Modeling vehicle interactions via modified LSTM models for trajectory prediction”. IEEE Access, v. 7, p. 38287-38296, 2019. DOI: [10.1109/ACCESS.2019.2907000](https://doi.org/10.1109/ACCESS.2019.2907000).
- Druck, S.; Carvalho, M. S.; Câmara, G.; Monteiro, A. V. M. (2004). “Análise espacial de dados geográficos”. Brasília: Embrapa.
- Ebel, P.; Gol, I. E.; Lingenfelder, C.; Vogelsang, A. (2020). “Destination prediction based on partial trajectory data”. In: 2020 IEEE Intelligent Vehicles Symposium (IV). IEEE. p. 1149-1155.
- Fan, H.; Yao, W. (2017). “A trajectory prediction method with sparsity data”. In: 2017 IEEE International Symposium On Parallel And Distributed Processing With Applications And 2017 IEEE International Conference On Ubiquitous Computing And Communications (ISPA/IUCC) (Anais...). IEEE. p. 1261-1265. DOI: [10.1109/ISPA/IUCC.2017.00191](https://doi.org/10.1109/ISPA/IUCC.2017.00191).
- Fu, T.-Y.; Lee, W.-C. (2020). “Trembr: Exploring Road Networks for Trajectory Representation Learning”. ACM Transactions on Intelligent Systems and Technology, v. 11, n. 1, p. 1–25. DOI: [10.1145/3361741](https://doi.org/10.1145/3361741).
- Imai, R.; Tsubouchi, K.; Konishi, T.; Shimosaka, M. (2018). “Early destination prediction with spatio-temporal user behavior patterns”. In: Proceedings Of The Acm On Interactive, Mobile, Wearable And Ubiquitous Technologies. v. 1, n. 4, p. 1-19. DOI: [10.1145/3161197](https://doi.org/10.1145/3161197).

- Jiang, M.; Li, C.; Li, K.; Liu, H. (2022). "Destination prediction based on virtual POI docks in dockless bike-sharing system". *IEEE Transactions On Intelligent Transportation Systems: A Publication Of The IEEE Intelligent Transportation Systems Council*. v. 23, n. 3, p. 2457–2470. DOI: [10.1109/TITS.2021.3099571](https://doi.org/10.1109/TITS.2021.3099571).
- Kitchenham, B.; Charters, S. (2007). "Guidelines for performing systematic literature reviews in software engineering".
- Lassoued, Y.; Monteil, J.; Gu, Y.; Russo G.; Shorten R.; Mevissen M. (2017). "A hidden Markov model for route and destination prediction." In: *2017 IEEE 20th International Conference On Intelligent Transportation Systems (ITSC)*. IEEE. p. 1-6. DOI: [10.1109/ITSC.2017.8317888](https://doi.org/10.1109/ITSC.2017.8317888).
- Liang, Y.; Zhao, Z. (2022). "NetTraj: A network-based vehicle trajectory prediction model with directional representation and spatiotemporal attention mechanisms". *IEEE Transactions On Intelligent Transportation Systems: A Publication Of the IEEE Intelligent Transportation Systems Council*. v. 23, n. 9, p. 14470–14481, 2022. DOI: [10.1109/TITS.2021.3129588](https://doi.org/10.1109/TITS.2021.3129588).
- Liu, Lingbo; Qiu, Zhilin; Li, Guanbin; Wang, Qing; Ouyang, Wanli; Lin, Liang. (2019). "Contextualized spatial-temporal network for taxi origin-destination demand prediction". *IEEE Transactions on Intelligent Transportation Systems*. v. 20, n. 10, p. 3875-3887. DOI: [10.1109/TITS.2019.2915525](https://doi.org/10.1109/TITS.2019.2915525).
- Ma, W.; Xie, H. (2021). "Research on prediction algorithm of vehicle trajectory in front based on driving intention classification." In: *2021 4TH International Conference on Data Science and Information Technology*. (Anais...). New York, NY, USA: ACM, 2021. DOI: [10.1145/3478905.3478977](https://doi.org/10.1145/3478905.3478977).
- Ning, F. (2021). "Prediction and detection of urban trajectory using data mining and deep neural network". In: *2021 International Conference on Big Data Analysis and Computer Science (BDACS)*. (Anais...). IEEE, 2021. DOI: [10.1109/BDACS53596.2021.00017](https://doi.org/10.1109/BDACS53596.2021.00017).
- Qiao, S.; Han, N.; Wang J.; Li, R. -H; Gutierrez, L. A.; Wu, X. (2018). "Predicting long-term trajectories of connected vehicles via the prefix-projection technique". *IEEE transactions on intelligent transportation systems*. v. 19, n. 7, p. 2305–2315, 2018. DOI: [10.1109/TITS.2017.2750075](https://doi.org/10.1109/TITS.2017.2750075).
- Rainbow, B. A.; Men, Q.; Shum, H. P. H. (2021). "Semantics-STGCNN: A semantics-guided spatial-temporal graph convolutional network for multi-class trajectory prediction". In: *2021 IEEE International Conference on Systems, Man, and Cybernetics (SMC)*. (Anais...). IEEE. p. 2959-2966. DOI: [10.1109/SMC52423.2021.9658781](https://doi.org/10.1109/SMC52423.2021.9658781).
- Ren, C. et al. (2022). "Mapping grade-separated junctions in detail using crowdsourced trajectory data". *IEEE Transactions On Intelligent Transportation Systems: A Publication Of The IEEE Intelligent Transportation Systems Council*. v. 23, n. 6, p. 5552–5561. DOI: [10.1109/TITS.2021.3054910](https://doi.org/10.1109/TITS.2021.3054910).
- Sadri, A. et al. (2018). "What will you do for the rest of the day?: An approach to continuous trajectory prediction". In: *Proceedings Of The AcM On Interactive, Mobile, Wearable And Ubiquitous Technologies*. v. 2, n. 4, p. 1–26, 2018. DOI: [10.1145/3287064](https://doi.org/10.1145/3287064).

- Santana, A. V.; Campos, J. (2017). "Travel history: Reconstructing semantic trajectories based on heterogeneous social tracks sources." In: Proceedings Of The 22nd Brazilian Symposium On Multimedia And The Web. (Anais...). New York, NY, USA: ACM. DOI: [10.1145/2976796.2976854](https://doi.org/10.1145/2976796.2976854).
- Selvaraj, D. C. et al. (2021). "Edge learning of vehicular trajectories at regulated intersections." In: 2021 IEEE 94TH Vehicular Technology Conference (VTC2021-FALL). (Anais...). Norman, OK, USA: IEEE. p. 1-7. DOI: [10.1109/VTC2021-Fall52928.2021.9625570](https://doi.org/10.1109/VTC2021-Fall52928.2021.9625570).
- Tang, L.; Duan, Z.; Zhu, Y.; Ma, J.; Liu, Z. (2021). "Recommendation for ridesharing groups through destination prediction on trajectory data". IEEE Transactions On Intelligent Transportation Systems: A Publication Of The IEEE Intelligent Transportation Systems Council. v. 22, n. 2, p. 1320–1333. DOI: [10.1109/TITS.2019.2961170](https://doi.org/10.1109/TITS.2019.2961170).
- Tong, P.; Du, W.; Li, M.; et al. (2021). "Last-mile school shuttle planning with crowdsensed student trajectories". IEEE Transactions On Intelligent Transportation Systems: A Publication Of The IEEE Intelligent Transportation Systems Council. v. 22, n. 1, p. 293–306. DOI: [10.1109/TITS.2019.2956786](https://doi.org/10.1109/TITS.2019.2956786).
- Vahedian, A.; Zhou, X.; Tong, L.; Li, Y.; Luo, J. (2017). "Forecasting gathering events through continuous destination prediction on big trajectory data". In: Proceedings Of The 25th Acm Sigspatial International Conference On Advances In Geographic Information Systems. (Anais...). New York, NY, USA: ACM, 2017. DOI: [10.1145/3139958.3140008](https://doi.org/10.1145/3139958.3140008).
- Wang, L.; Yu, Z.; Guo, B.; Ku, T.; YI, F. (2017). "Moving destination prediction using sparse dataset: A mobility gradient descent approach". ACM transactions on knowledge discovery from data. v. 11, n. 3, p. 1–33. DOI: [10.1145/3051128](https://doi.org/10.1145/3051128).
- Weintrit, A. (2017). "The concept of time in navigation. TransNav the International Journal on Marine Navigation and Safety of Sea Transportation". v. 11, n. 2, p. 23–33. DOI: [10.12716/1001.11.02.01](https://doi.org/10.12716/1001.11.02.01).
- Wu, H.; Wang, L.; Zheng, S.; Xu, Q.; Wang, J. (2020). "Crossing-road pedestrian trajectory prediction based on intention and behavior identification." In: 2020 IEEE 23rd International Conference On Intelligent Transportation Systems (ITSC). (Anais...). Rhodes, Greece: IEEE, 2020. p.1–6. DOI: [10.1109/ITSC45102.2020.9294491](https://doi.org/10.1109/ITSC45102.2020.9294491).
- Yuan, H.; Li, G. (2019). "Distributed in-memory trajectory similarity search and join on road network." In: 2019 Ieee 35th International Conference On Data Engineering (ICDE). (Anais...). IEEE, 2019. p.1262–1273. DOI: [10.1109/ICDE.2019.00115](https://doi.org/10.1109/ICDE.2019.00115).
- Zhang, W.; Liu, Y.; Liu, T.; Yang, C. (2018). "Trajectory prediction with recurrent neural networks for predictive resource allocation". In: 2018 14TH IEEE International Conference On Signal Processing (ICSP). (Anais...). IEEE. DOI: [10.1109/ICSP.2018.8652460](https://doi.org/10.1109/ICSP.2018.8652460).